

# 物体把持のための 3 次元点群の位相構造の学習と特徴抽出

## Topological Structure Learning and Feature Extraction of 3D Point Clouds for Grasping

正 戸田 雄一郎 (首都大) 学 北井 瑳佳 (首都大)  
 正 武居 直行 (首都大) 正 和田 一義 (首都大)  
 ○正 久保田 直行 (首都大)

Yuichiro TODA, Tokyo Metropolitan University, ytoda@tmu.ac.jp  
 Sasuga KITAI, Tokyo Metropolitan University  
 Naoyuki TAKESUE, Tokyo Metropolitan University  
 Kazuyoshi WADA, Tokyo Metropolitan University  
 Naoyuki KUBOTA, Tokyo Metropolitan University

Recently, the expectation to rescue robots has been increasing much in order to perform the monitoring in disaster areas. However, there are many critical problems in rescue robots. Especially, we must improve the perceptual system of the rescue robot by using 3D measurement sensor. In this paper, we discuss the learning method of topological structure from 3D point cloud and introduce our Sokuiki sensor array system for measuring 3D distance data. Next we explain Batch-Learning Growing Neural Gas (BL-GNG) for learning the topological structure. Furthermore, we apply BL-GNG to extract the topological structure of a ladder. Finally, we show several experimental results of the proposed method.

**Key Words:** Growing Neural Gas, 3D Point Cloud Processing, Environmental Sensing

### 1. 緒言

近年、災害ロボットの分野において、被災地における二次被害を避けるために、被災地においても頑健に行動できる災害ロボットの開発が望まれている。被災地において、安全かつ迅速にロボットが行動をするためには、移動ロボットが環境地図と自己位置を認識し、次の移動経路を推定する必要がある。このような屋外環境における環境認識技術に対して、近年、Lidar などの 3 次元距離計測センサを用いた研究が盛んに行われている[1,2]。このような研究では、3 次元点群データを用いることによって、3 次元モデルを生成し、生成されたモデルからロボットが移動に必要な 3 次元の経路計画や移動の際に必要な路面状態の推定などを行なうことによって、ロボットの屋外におけるより頑健な行動を実現している [3]。災害現場の移動時において、梯子や階段の移動を行うためにロボットにとって物体を把持する能力は必要不可欠であり、ロボットには様々な形状の物体把持が求められる。また、物体把持を行うためには、対象物となる物体の認識や形状把握を行う必要があり、近年では、深層学習の発展により、教師あり学習を用いた把持対象の認識に関する研究が多く行われている [4]。しかしながら、このような教師あり学習を用いた研究では、未知の物体に対する認識性能や物体把持においては、ロボットの視点ごとに異なる形状の計測データが得られることから学習が困難であるなどといった問題点が存在する。そのような中、我々は、得られた 3 次元点群データから最低限の位相構造を学習し、把持位置の算出を行うことで、未知な物体に関しても把持位置の推定を行うことが可能な手法を実現するために、未知なデータ分布から位相構造の学習が可能な教師なし学習の 1 つである Batch Learning Growing Neural Gas (BL-GNG)を用いた位相構造の学習を提案し、形状把握に必要な特徴量抽出に関する手法の提案を行ってきた [5]。BL-GNG は、Fritzke によって提案されたオンライン学習手法である GNG[6]を一括学習することで学習の安定性を高めた手法であり、3 次元点群データに適用することによって、法線ベクトルや曲率などの特徴量が抽出可能な手法となっている。本稿では、梯子昇降における持ち手の幾何構造の抽出として、位相構造全体の平均次数の観点から、BL-GNG のノード数を決定し、梯子の位相構造を抽出する手法の提案を行う。

### 2. 可変型測域センサアレイ

本研究において開発を行なった測域センサアレイを図 1 に示す。図 1 (a)は、センサアレイの基本モジュールを表し、2 個の Laser Range Finder (LRF) と 2 個のアクチュエータから構成されており、図 2 に示すシステム構成図によりデータ計測を行なうシステムとなっている。測域センサアレイは、この基本モジュールを図 1 (b)のように複数個組み合わせることによって、計測を行なう。本稿において使用した LRF と LRF を回転させるためのアクチュエータの仕様を表 1, 2 に示す。モータの回転軸と LRF の光軸を一致させることによって最低限の座標変換により 3 次元復元が可能なものとなっている。また、LRF におけるミラーの回転軸が一致しているため、この軸方向に対して基線の軸を持つセンサアレイシステムとなっており、本稿では、この基本モジュールら構成される 2 つの LRF から得られた距離の視差を用いて特徴点抽出を行なう。

### 3. Batch Learning Growing Neural Gas を用いた梯子の把持位置の検出

可変型測域センサアレイによって 3 次元点群の取得後、梯子形状のような細い構造を持つ物体の形状特徴量の抽出を行う際に、3 次元点群データに対して位相構造の学習を行なうことは、LRF に含まれる計測誤差やセンサの分解能の観点から困難であることが想定される。そこで本研究では、可変型測域センサアレイから取得された 2 次元の距離画像上で位相構造の学習を行ない、距離画像で得られた位相構造を 3 次元空間へ変換することによって、3 次元空間上における梯子の幾何的構造の抽出を行なう。全体のアルゴリズムのフローチャートを図 3 に示す。詳細な BL-GNG のアルゴリズムに関しては、[5]で提案されているため、本稿では、安定的な学習を可能にしている部分についてのみ説明していく。

#### 3.1 学習則


従来の GNG の学習ではランダムサンプリングにより学習データを選択し、第 1 勝者ノードと結合関係を持つノードの位置も更新される。その際に、各ノードの学習には固定値の学習率が用いられるため、一般的な GNG の学習においては、学

Table 1 Specification of UST10LX

検出距離	0.06～20[m]
測距精度	± 40 [mm]
走査角度	270 [°]
走査時間	25 [msec]
角度分解能	0.25 [°]
インターフェース	Ethernet 100BASE-TX

Table 2 Specification of FHA-8C

減速比	50
瞬間最大トルク [N・m/A]	3.3
最大回転速度[r/min]	120
トルク定数	1.3
一方向位置決め精度 [Sec]	120
検出分解能	400000
エンコーダ形式	アブソリュート



(a) Basic module (b) A configuration example  
Fig. 1 Sokuiki sensor array

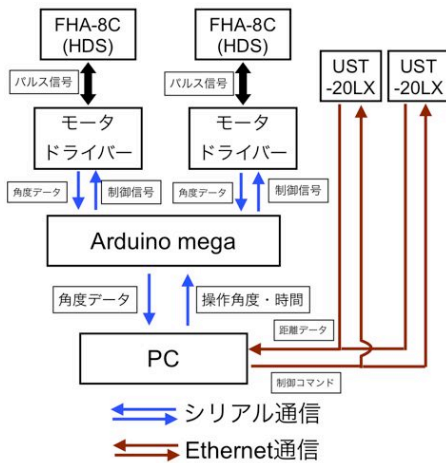


Fig.2 System configuration



Fig.3 Total Algorithm

学習が収束せずノードの位置が安定しない. BL-GNG では, 以下の式のように Fuzzy C-means の目的関数を用いる.

$$J_{\text{BL-GNG}} = \sum_{n=1}^N \sum_{k=1}^K (u_{nk})^m \|v_n - w_k\|^2 \quad (1)$$

ここで,  $u_{nk}$  は  $k$  番目のノード  $w_k$  の  $n$  番目のデータ  $v_n$  に対するメンバシップ関数の値,  $m$  はあいまい度を表す. Fuzzy C-means における目的関数は収束することが知られており, 3次元点群データにおけるノード位置の決定では, 振動せず安定した位相構造の学習が必要であるため, BL-GNG における目的関数として用いた.

式(1)から, 時刻  $t$  におけるノードの更新則は次のように定義される.

$$w_i^{(t)} = \frac{\sum_{j=1}^K u_{ji}^m \cdot (v_j - w_i^{(t-1)})}{\sum_{j=1}^K u_{ji}^m} \quad (2)$$

ここで,  $N$  は入力データ数を表す.

このように, BL-GNG の学習則では, Fuzzy C-means に基づく定式化を行なってきたため, メンバシップ関数は以下の条件を満たさなければならない.

$$\begin{aligned} u_{nk} &\in [0,1]; \quad 1 \leq n \leq N; \quad 1 \leq k \leq C; \\ \sum_{i=1}^C u_{ni} &= 1; \quad 1 \leq n \leq N; \\ \sum_{j=1}^N u_{jk} &> 0; \quad 1 \leq k \leq C; \end{aligned} \quad (3)$$

この条件式から, BL-GNG におけるメンバシップ関数を以下の式により定義を行なう.

$$u_{ji} = \frac{1}{\left( \frac{d_{i,j}}{d_{s_1,j}} + \sum_{c_{k,s_1}=1}^C \frac{d_{i,j}}{d_{k,j}} \right)^{1/m-1}} \quad (4)$$

式(4)は第1勝者ノード  $s_1$  となるノードとそのノードと結合関係を持つノードのみに影響を与えるメンバシップ関数となっている. このため, 式(3)の3番目の条件式を満たさないノードが発生する可能性が考えられる. 全データを用いて学習を行なう場合の BL-GNG では, そのようなノードの削除を行うことによって, 式(3)の条件式を満たす. このような処理は, データの分布が動的に変化することを考慮に入れた GNG であ

る GNG with Utility value (GNG-U) の Utility 値におけるしきい値処理を近似したような処理となっている。

ここで、式(4)のメンバシップ関数を用いる意味合いを考えると、前述のとおりこの式は第 1 勝者ノードとそのノードと結合関係を持つノードのみを Fuzzy C-means の観点からクラスタリングを行なっていく手法となっており、Fuzzy C-means では、1つのデータに対して全てのノードのメンバシップ関数を計算し、次のステップの位置を計算していくことと考えると、BL-GNG では、1つのデータに対して第 1 勝者ノードとその近傍に対するベクトルの量子化を行っていく挙動となっており、部分的な最適化を行なっていくことで全体としての最適化を行なっていく手法だと考えることができる。

### 3・2 初期化

GNG 本来のアルゴリズムでは、初期化時におけるノード数を 2 として学習を行うが、Batch Learning を行なう際には、所望のノード数にいたるまで、全データを見ながら学習を行なっていくため、膨大な計算時間が必要となってしまうといった問題点が存在する。しかしながら、提案を行なった結合関係の更新則を用いることにより、初期化時に、任意のノード数において初期化を行なうことが可能となる。具体的には Algorithm 1 のように、任意のノード数  $M$  だけ入力データを選択し、その位置に対してノードを発生させる。このとき全てのノードの結合関係は  $c_{ij}=0$  (未結合状態) とする。このようにノードを発生させることによって、Batch Learning の学習によって自動的にエッジが接続され初期化を所望のノード数で学習を開始させることが可能となる。

#### Algorithm 1 Initialization:

**Input:** Input dataset  $V$ , Number of initial nodes  $M_{\text{init}}$

**Output:** Set of node  $W$  and Adjacency Matrix  $C$

1: for  $j=1$  to  $M_{\text{init}}$  do

2:     Select the  $k$ th input vector randomly

3:      $w_j = v_k$

4: end for

5: for  $j=1$  to  $N$  do

6:      $s_1 = \arg \min_{i \in A} \|v_j - w_i\|$

7:      $s_2 = \arg \min_{i \in A \setminus \{s_1\}} \|v_j - w_i\|$

8:      $a_{s_1, s_2} = 1$

9: end for

10: for  $i=1$  to  $M_{\text{init}}$  do

11:     for  $j=1$  to  $M_{\text{init}}$  do

12:         if  $g_{ij} = 1$  then

13:              $c_{ij} = 1$

14:         else

15:              $c_{ij} = 0$


16:         end if

17:     end for

18: end for

### 3.3 BL-GNG を用いた梯子検出のための位相構造の学習

BL-GNG を用いることによって、3次元点群データの位相構造は学習可能であるが、梯子のような長細い幾何構造を持つ物体における LRF の計測データには、多くの計測誤差が含まれたり、計測のデータ数が少なくなってしまうため、3次元点群データに対し、BL-GNG による学習を行なってしまう



(a) Before node deletion (b) After node deletion

Fig. 4 Concept image of node deletion

うと、適切な位相構造が学習できないことが考えられる。そこで本研究では、測域センサアレイから計測された距離データを距離画像として使用し、2次元の距離画像に対して BL-GNG による位相構造学習を行うことによって、梯子に対する位相構造の学習を行なう。具体的には、測域センサアレイにより周囲の環境情報の計測後、不必要なデータである床面の除去を3次元点群データを用いて行う。その後、2次元の距離画像を用い、領域成長法を用いることにより、3次元点群データの領域分割を行う。この際、領域分割に用いる類似度の指標  $\tau_{ij}$  として、以下の式で表される隣り合う画素同士の距離の絶対値差分を用いる。

$$\tau_{ij} = |d_i - d_j| \quad (5)$$

ここで、 $d_i$  は、 $i$  番目のピクセルの距離を表す。式(5)により、指標  $\tau_{ij}$  を計算し、 $\tau_{ij}$  が一定のしきい値  $\sigma$  以内であれば同一の領域、しきい値よりも大きければ異なる領域として、領域成長法により領域分割を行なっていく。

領域分割後、梯子形状の幾何構造を学習するために、各領域において BL-GNG による位相構造の学習を行なっていく。BL-GNG により、適切な位相構造を学習するためには、形状把握に必要なノード数を定義する必要がある。また、BL-GNG のような競合学習のアルゴリズムにおいては、入力データに対して第 1 勝者ノードの決定を行わなければならないため、ノード数が少なれば少ないほど位相構造学習にかかる計算時間は少なくなるため適切であることが考えられる。そこで、本稿では学習した位相構造における平均次数により、ノード数の決定を行う。具体的に、本研究で把持対象とした梯子形状は上述のとおり、長細い構造であることが想定されるため、ノードの次数として、ある注目ノードの両端にノードが存在する次数 2 の構造が多く存在する幾何構造が適切であることが考えられる。そこで、初期ノードの個数として、 $M_{\text{init}}=2$  とし、BL-GNG における全体のノードの平均次数が 2.5 を超えた時点で、ノードの追加を行わないことによって、ノード数の決定を行なう。

ノード数の決定後、BL-GNG による学習により、構築された位相構造は、距離画像上で学習を行っているため、2次元の位相構造となっている。そのため、各ノードに対して第 1 勝者ノード  $s_1$  を算出し、その 3次元座標を各ノードの位置とすることによって、位相構造の 2次元空間から 3次元空間への変換を行なう。このようにして、3次元空間上での梯子把持のための位相構造学習を行なっていくが、学習された位相構造は、データの密度分布に基づいてノードが配置されるため、梯子の幾何形状を表すのに不必要なノードが存在してしまう (図 4 (a))。そこで本研究では、次数が 2 のノードに対して、ノードのなす角  $\theta$  を計算し、 $\theta$  があるしきい値  $\beta$  よりも大きい場合にノードを削除し、両端のノードに新たに結合関係を持たせることによって、ノードの幾何構造の抽出を行なう。

## 4. 実験結果

本実験では、ImPACT タフ・ロボティクス・チャレンジのフィールド評価会において屋内フィールドで使用している梯子のデータを計測し、提案手法において梯子の位相構造が学習可能かどうかの検証を行う。表 3 に、梯子の簡単な仕様が



示す。また、図 5 (a)に、計測した梯子画像、(b)に測域センサアレイにより計測を行なった距離画像を示す。さらにデータ計測後、3次元点群より床面の除去を行ない、床面が除去された距離画像から、領域分割を行なった結果を図 6 (a)に示す。図 6 (a)における左の紫色に分割された領域が梯子領域の一部となっており、この領域に対し、BL-GNG を適用した結果が図 6 (b)、3次元空間へ変換した結果が図 6(c) (緑色のノードとエッジが BL-GNG により学習された位相構造)となっている。このように、BL-GNG を用いることによって、梯子形状の大まかな位相構造を学習できていることが、梯子の棧の部分に冗長なノードが生成されており、幾何形状を適切に抽出できていないことが分かる。図 6(d)にノードの削除を行ない、BL-GNG において学習した位相構造から、幾何的な構造を抽出した結果を示すが、図 6(c)と比較して、棧から冗長なノードが除去できており、梯子形状の幾何的な構造を抽出できていることが分かる。この時、抽出された幾何形状から算出された棧の幅は、平均で 574mm であり、全体幅の 620mm と比較して、ほぼ同等の大きさとなっていることが分かる。位相構造の上部に行くほどより簡素な幾何的形状が得られているのは、梯子の上部のデータ密度が小さいため、中心部のところと比較すると簡素な幾何的形状で表されていると考えられる。

## 5. 結言

本研究は、測域センサアレイから計測された 3 次元点群データを用いた梯子の把持位置検出のためのアルゴリズムの提案を行なった。具体的には、計測された 3 次元点群から不必要なデータである床面の除去を行ない、床面が除去された距離画像において BL-GNG で位相構造を学習することにより、梯子のような長細い形状を持つ物体に対しても BL-GNG における位相構造学習が行えることを示した。さらに、学習後の位相構造から冗長なノードを削除することによって、梯子のもち手部分である棧の位置検出を行えることを示した。

本研究では、領域分割を行ない、BL-GNG の入力データ数を削減したため、オンラインにおける BL-GNG の学習が可能であったが、データの入力数が増加するに連れて、BL-GNG では、計算時間が増加してしまうといった問題点が存在する。今後の課題として、BL-GNG をミニバッチ学習化することによる学習の高速化手法を提案することなどがあげられる。




(a) Measuring environment (b) Distance image


Fig. 5 Experimental environment

Table 3 Specification of ladder

棧の直径 [mm]	30
全体幅 [mm]	620



(a) Region segmentation (b) BL-GNG (depth image)



(c) BL-GNG (3D point cloud)(d) Extraction of topological structure  
Fig.6 Experimental result

## 6. 謝辞

本研究は、総合科学技術・イノベーション会議により制度設計された革新的研究開発推進プログラム(ImPACT)により、科学技術振興機構を通して委託されたものです。

## 文 献

- [1] Ning, Xiaojuan, et al. "Segmentation of architecture shape information from 3D point cloud." Proceedings of the 8th International Conference on Virtual Reality Continuum and its Applications in Industry. ACM, 2009.
- [2] J. Strom, A. Richardson, E. Olson, "Graph based segmentation of colored 3d laser point clouds", In Proc. of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2010.
- [3] Murphy, Robin R., et al. "Search and rescue robotics." Springer Handbook of Robotics. Springer Berlin Heidelberg, p.1151-1173,2008.
- [4] 飯塚正樹, 秋月秀一, 橋本学, "アフォーダンスの概念に基づく一般物体認識のための 3 次元特徴量", 第 34 回日本ロボット学会学術講演会, 2016.
- [5] 戸田雄一郎, 久保田直行, "Batch Learning Growing Neural Gas による 3 次元点群の位相構造の学習", ビジョン技術の実用ワークショップ ViEW2014, 2014.
- [6] B. Fritzke: A growing neural gas network learns topologies; Advances in Neural Information Processing Systems, Vol. 7, pp. 625-632, 1995.